

Análise Comparativa das Principais Técnicas de Otimização por Enxame de Partículas no Problema de Despacho Ótimo de Reativos

Andrey da Costa Lopes

Elzilene Paiva Garcia

Jessica Mieko Onaka Alves Meira

João Dilberto Mulinetti da Silva Junior

Departamento de Ciências Exatas e Tecnológicas

Universidade Federal do Amapá, UNIFAP

Macapá, Brasil

José Henrique Dias de Souza

Departamento de Ciências Exatas e Tecnológicas

Universidade Federal do Pará, UFPA

Belém, Brasil

Resumo— Neste trabalho é apresentado um estudo comparativo do desempenho de algumas das principais variações das Técnicas de Otimização por Enxame de Partículas (TOEP), sendo elas: TOEP com fator de Inércia; TOEP com variação nos fatores cognitivo e social, e; TOEP com fator de constrição. Essas três variações, bem como a TOEP clássica serão detalhadas no trabalho e serão as ferramentas de otimização aplicadas no problema de despacho ótimo de reativo em sistemas elétricos de potência. Os algoritmos foram aplicados no sistema IEEE 6 barras, para uma determinada condição de operação. Os resultados das simulações mostraram que todos esses métodos são viáveis para esse caso, tendo a TOEP com variação nos fatores cognitivo e social se destacado em relação aos demais.

Palavras-chave -- Otimização por enxame de partículas, Despacho Ótimo de Reativos, Sistemas elétricos de potência.

I. LISTA DE SÍMBOLOS

N_R : Número de ramos da rede;

N_G : Número de barras de geração;

N_{PQ} : Número de barras de carga;

N_T : Número de transformadores;

N_C : Número de compensadores shunts;

θ_{ij} : diferença de ângulo de tensão entre as barras i e j (rad)

B_{ij} susceptância de transferência entre as barras i e j (p.u.)

G_{ij} : condutância de transferência entre as barras i and j (p.u.);

P_{Di} : Potência ativa demandada na barra i (p.u.);

Q_{Di} : Potência reativa demandada na barra i (p.u.);

P_{Gi} : Potência ativa gerada na barra i (p.u.);

Q_{Gi} : Potência reativa gerada na barra i (p.u.);

Q_{Ci} : reactive power source installation at bus i (p.u.);

$P_{perdas_{NR}}$: Perdas ativas no ramo NR (p.u.);

T_k : posição do tap do transformador k ;

V_i : módulo da tensão na barra i (p.u.);

V_{PQi} : módulo da tensão na i -ésima barra PQ (p.u.);

V_{Gi} : módulo da tensão na i -ésima barra PV (p.u.);

II. INTRODUÇÃO

As constantes mudanças que o Setor Elétrico brasileiro tem sofrido nos últimos anos trazem consigo novos desafios, quer seja pela demanda crescente quer seja pela adequação ao arcabouço normativo que regula o setor. Nesse contexto, cabe ao planejamento das grandes concessionárias e permissionárias elaborar estratégias de operação a fim de garantir o funcionamento robusto, seguro, confiável e eficiente do sistema elétrico de potência.

Ao que se percebe, manter as variáveis elétricas, como por exemplo, o perfil de tensão nas barras, cujos limites são estipulados por normas reguladoras, não é tarefa trivial. Em se tratando de eficiência, remete-se naturalmente ao problema de fluxo ótimo de potência em que uma de suas vertentes utiliza o despacho ótimo de reativos para controlar as variáveis desejadas no sistema.

O crescimento do Sistema Interligado Nacional (SIN), que recentemente integrou a as cidades de Manaus e Macapá, totalizando 98,3% da energia requerida pelo país, tem sido fonte de motivação prática para alavancar as pesquisas relacionadas ao despacho ótimo de reativos (DOR), o qual sempre encontrou relevância pelos pesquisadores do mundo todo. Pelo lado da demanda, o cenário de mudanças constantes

não é diferente: a inserção de geração distribuída e os problemas de qualidade de energia são bons exemplos.

Entende-se DOR como um problema de otimização não-linear e não convexo e de grande porte que determina um conjunto de variáveis ótimas de estado e controle da rede elétrica, a partir dos dados de carga e dos parâmetros do Sistema Elétrico de Potência (SEP). O problema de DOR otimiza uma função objetivo enquanto satisfaz um conjunto de restrições físicas e operacionais impostas pelas limitações dos equipamentos e exigências de segurança [1].

Muitas técnicas clássicas de otimização têm sido utilizadas para solucionar o problema de DOR, tais como programação linear e não linear, programação quadrática, assim como, soluções por método de Newton. Percebe-se, no entanto, o uso cada vez mais gradativo de metaheurísticas, tanto aquelas baseadas nas teorias do evolucionismo quanto as baseadas na inteligência de enxames. A esta última categoria pertence a Técnica de Otimização por Enxame de Partículas (TOEP) que ganhou notoriedade na resolução do problema de DOR, conforme pode ser verificado em [1] - [4].

III. TÉCNICA DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

A TOEP foi introduzida por Kennedy e Eberhart em 1995 a partir da observação da natureza, especificamente do comportamento de pássaros e de peixes. Conforme mencionado anteriormente, a TOEP faz parte de um grupo de técnicas de otimização baseado na observação de sociedades biológicas, ou inteligência de enxames, conforme classificações de trabalhos na área. Seus principais pontos de observação são comportamento cognitivo (ou individual) e o comportamento social (baseado na coletividade), ou seja, em uma eventual busca por alimento ou abrigo, os indivíduos que compõe o enxame (denominadas partículas) serão influenciados simultaneamente pela autopercepção e pelo desempenho do melhor indivíduo [5], [6].

Observando os pássaros em voo, é possível notar que há um pássaro que se sobressai na frente dos demais. Esse pássaro possui a melhor posição do grupo e os outros pássaros o seguem. Como eles estão em movimento, há sempre a atualização das posições de cada um. Analogamente, no TOEP, esse pássaro que se sobressai seria a partícula de melhor posição (Gbest) e as melhores posições dos demais pássaros até momento seriam as melhores posições das partículas (Pbest).

IV. PRINCIPAIS VARIAÇÕES DA TOEP

Assim como outras técnicas de otimização amplamente usadas na resolução de problemas de engenharia, a TOEP também apresenta algumas variações propostas ao longo dos anos. Destacam-se as principais variações da TOEP: TOEP com fator de Inércia variando ao longo das iterações (PSO-TVIW); TOEP com variação nos fatores cognitivo e social (PSO-TVAC), e; TOEP com fator de construção (PSO-CF). Essas 3 variações bem como a TOEP clássica serão as ferramentas de otimização usadas para resolver o problema de

DOR e, por esse motivo, merecem a descrição detalhada feita nos itens a seguir.

A. Método Clássico

Num espaço vetorial real, cada solução individual possível pode ser modelada como uma partícula que se move através do hiperespaço $\mathfrak{R}^M$ do problema. A posição de cada partícula é determinada pelo vetor $X_i(t) \in \mathfrak{R}^M$ e estas se movem com uma velocidade $V_i(t) \in \mathfrak{R}^M$. Num instante t , o vetor posição e o vetor velocidade da i -ésima partícula no espaço de busca D -dimensional podem ser representados como:

$$X_i(t) = \{x_{i,1}(t); x_{i,1}(t); \dots; x_{i,d}(t); \dots; x_{i,D}(t)\} \quad (1)$$

$$V_i(t) = \{v_{i,1}(t); v_{i,1}(t); \dots; v_{i,d}(t); \dots; v_{i,D}(t)\} \quad (2)$$

De acordo com função objetivo formulada pelo problema, define-se a melhor posição de cada partícula i como:

$$Pbest_i(t) = \{pbest_{i,1}(t); \dots; pbest_{i,d}(t); \dots; pbest_{i,D}(t)\} \quad (3)$$

A posição da partícula mais apta encontrado até então no instante t é dada por:

$$Gbest(t) = \{gbest_1(t); \dots; gbest_d(t); \dots; gbest_D(t)\} \quad (4)$$

Em seguida, as novas velocidades e posições das partículas para a próxima avaliação da melhor aptidão são calculadas usando as duas equações seguintes:

$$V_i(t+1) = V_i(t) + c_1 \cdot r_1 [Pbest_i - X_i(t)] + c_2 \cdot r_2 [Gbest - X_i(t)] \quad (5)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (6)$$

Na equação (5), " $V_i(t+1)$ " representa a atualização da velocidade da partícula a partir de um tempo inicial, $V_i(t)$. As incógnitas c_1 e c_2 são as constantes de aceleração que influenciam diretamente os fatores cognitivo e social, respectivamente. Os termos r_1 e r_2 são funções randômicas cujas saídas contínuas variam entre 0 e 1. É importante avaliar, de acordo com cada algoritmo, qual dos fatores deverá ser preponderante. Sendo que na literatura [6], [7], usualmente utiliza-se os c_1 e c_2 com soma igual a 4 (quatro). Quando c_1 é maior do que c_2 , a partícula sofrerá maior influência do Pbest, ou seja, a interação entre as partículas é menor, o que diminui a convergência do algoritmo. Em contrapartida, se c_2 for maior do que c_1 , a partícula sofrerá maior influência do Gbest, e facilmente ficará presa em ótimos locais para problemas complexos, mas pode ter um bom desempenho na resolução de alguns problemas específicos.

A fórmula (6) refere-se a atualização da posição da partícula no decorrer do tempo.

B. Método com o fator inércia (ω)

A primeira das variações do algoritmo clássico, também proposta pelos autores originais, diz respeito à inserção de um peso na parcela referente à velocidade da partícula na iteração

anterior ($V_i(t)$), conhecido como fator de inércia (ω). Analogamente aos algoritmos baseados nas teorias evolutivas, o fator de inércia teria a função de garantir a diversidade do algoritmo. [7]. A equação abaixo mostra a inserção do fator (ω) na versão original da equação da velocidade da partícula.

$$V_i(t+1) = \omega V_i(t) + c_1 r_1 [Pbest_i - X_i(t)] + c_2 r_2 [Gbest_i - X_i(t)] \quad (7)$$

É importante ressaltar que o valor do fator de inércia determina o quão as partículas são dependentes da velocidade inicial. Com um fator de inércia baixo, como por exemplo, 0,4, as partículas convergem mais rapidamente para um ótimo, sendo que esse valor pode ser apenas um ótimo local. Com um fator de inércia maior, como por exemplo 1,2; as partículas teriam maior independência das parcelas cognitivas e sociais, o que consequentemente dificultaria a convergência para um ótimo. Na literatura nota-se a utilização do valor do fator de inércia igual 0,8, pois permite que a partícula tenha liberdade para procurar a solução ótima do sistema pelo espaço de busca, como também tenha influência das parcelas cognitiva e social, para convergir para um valor ótimo. [8]

Outros trabalhos mostram que a variação do fator de inércia com o número de iterações ajuda na convergência do algoritmo para o ótimo global, ou seja, contribui para evitar a convergência para ótimos locais. Essa técnica é conhecida como *Time-Varying Inertia Weight* (TVIW) e atua como uma espécie de controle da convergência, decrescendo o fator de inércia a medida que a simulação avança nas iterações [9]. Em geral, o peso de inércia ω varia linearmente de forma decrescente, passando de 0,9 até 0,4, durante a execução do algoritmo. A equação que descreve este processo é dada por (8).

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{iter_{\max}} \times iter \quad (8)$$

C. Método com o fator de restrição(k)

Outra proposta para melhorar o algoritmo original foi a inserção do fator de restrição, também conhecido na literatura como fator de aceleração. [10] O fator de restrição foi proposto a fim de assegurar a convergência do algoritmo sem que seja necessário impor qualquer restrição de velocidade na fórmula de atualização de velocidade, conforme a equação (9):

$$V_i(t+1) = k \cdot \{V_i(t) + c_1 r_1 [Pbest_i - X_i(t)] + c_2 r_2 [Gbest_i - X_i(t)]\} \quad (9)$$

Em que a constante k é o fator de restrição, o qual é descrito pela equação (8).

$$k = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}}, \quad \varphi = c_1 + c_2 \quad (10)$$

Em vários testes, o enxame tem convergência estável sempre que $\varphi \geq 4$. Recomenda-se um valor de 4,1 para a soma de c_1 e c_2 , o que leva a $k = 0,7298$ e $c_1 = c_2 = 2,05$.

D. Variação das constantes de aceleração

A técnica de variação das constantes de aceleração (TVAC – *Time Varying Acceleration Coefficients*), consiste em imprimir uma variação às constantes c_1 e c_2 , tal como àquela proposta para o fator de inércia [11].

Os inúmeros trabalhos propostos a analisar as características da TOEC, apontam que aumentando o fator cognitivo sem, contudo, alterar o fator social geralmente leva o algoritmo a não convergir. Por outro lado, o aumento do fator social mantendo inalterado o valor do fator cognitivo pode levar o algoritmo à convergência precoce, haja vista a TOEC ser altamente elitista. Buscando o equilíbrio entre a convergência e a diversidade, a TVAC surge como boa alternativa para problemas multimodais, tais como o explorado neste trabalho. As equações (11) e (12) mostram as variações das constantes c_1 e c_2 , respectivamente, da forma como foram usadas neste trabalho. c_{1i} e c_{2i} são os valores iniciais para as constantes de aceleração enquanto c_{1f} e c_{2f} são os valores finais definidos para as mesmas constantes.

$$c_1 = (c_{1f} - c_{1i}) = \frac{iter}{iter_{\max}} + c_{1i} \quad (11)$$

$$c_2 = (c_{2f} - c_{2i}) = \frac{iter}{iter_{\max}} + c_{2i} \quad (12)$$

V. FORMULAÇÃO DO PROBLEMA

A função objetivo principal é minimizar as perdas de potência ativa do sistema. As variáveis de controle são as tensões nas barras de geração, a posição dos *taps* dos transformadores e os bancos de capacitores chaveados. As restrições de igualdade são as equações de balanço dos fluxos de potência ativa e reativa, automaticamente satisfeitas pelo cálculo do fluxo de carga, e as restrições de desigualdade incluem os limites de tensão nas barras, limites de potência reativa nos geradores, limite da capacidade de potência reativa dos bancos de capacitores e os limites da posição dos *taps* dos transformadores.

A. Função Objetivo:

$$\begin{aligned} f_p &= \min \sum_{NR} P_{NR}^{perdas} \\ &= \min \sum_{NR} G_{ij} (V_i^2 + V_j^2 - 2V_i V_j \cos \theta_{ij}) \end{aligned} \quad (13)$$

B. Restrições de igualdade:

$$P_{Gi} - P_{Di} - V_i \sum_{j \neq i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \quad (14)$$

$$Q_{Gi} - Q_{Di} - V_i \sum_{j \neq i} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \quad (15)$$

C. Restrições de desigualdade:

$$\begin{aligned}
 V_{Gi}^{\min} &\leq V_{Gi} \leq V_{Gi}^{\max} & i \in N_G \\
 V_{PQi}^{\min} &\leq V_{PQi} \leq V_{PQi}^{\max} & i \in N_{PQ} \\
 T_k^{\min} &\leq T_k \leq T_k^{\max} & k \in N_T \\
 Q_{Gi}^{\min} &\leq Q_{Gi} \leq Q_{Gi}^{\max} & i \in N_G \\
 Q_{Ci}^{\min} &\leq Q_{Ci} \leq Q_{Ci}^{\max} & i \in N_C
 \end{aligned} \quad (16)$$

No trabalho proposto, as variáveis de controles são autolimitadas. Já as desigualdades de Q_{Gi} e V_{PQi} podem ser incorporadas na função objetivo como termos de penalidade quadráticos. Portanto, a função objetivo pode ser aumentada por:

$$F_p = f_p + \sum_{i \in N_{PQ}} \lambda_{Vi} (V_i - V_i^{\lim})^2 + \sum_{i \in N_G} \lambda_{Gi} (Q_{Gi} - Q_{Gi}^{\lim})^2 \quad (17)$$

Onde λ_{Vi} e λ_{Gi} são fatores de penalidade e $x^{\lim}$ é o valor limite da variável dependente x dada como:

VI. SIMULAÇÕES E DISCUSSÕES

Todas as simulações para resolver o problema de DOR utilizando TOEP foram implementadas utilizando MATLAB 7.0 na plataforma Windows 8. Como se pode perceber, para cada partícula está associado um vetor com as variáveis independentes do algoritmo, cuja solução do problema de fluxo de carga determinará o estado do sistema para cada possível solução em particular. Nesse sentido, faz-se necessário o uso de uma ferramenta para o cálculo do fluxo de carga que além de robusta seja eficiente em se tratando do tempo demandado para sua execução uma vez que ela será determinante no tempo total gasto para a simulação. Neste trabalho utilizou-se a ferramenta computacional MATPOWER para desempenhar essa função. Salienta-se que o MATPOWER também foi desenvolvido em MATLAB e por esse motivo facilitou sua integração no algoritmo final.

A. Estudo de Caso para o sistema IEEE 6 barras

O sistema IEEE 6 barras, cujas características da linha, dados de carga, dentre outras informações podem ser encontrados em [2], mostrado na Figura 1, consiste de dois geradores localizados na barra 1 (barra de referência) e 2 (PV), cinco linhas, dois transformadores, localizados nos ramos 4-3 e 6-5. Para este estudo de caso, dois compensadores shunt capacitivos foram colocados nas barras 4 e 6. Os ajustes para os limites máximos e mínimos para configurações dos *taps* dos transformadores, compensadores shunts e tensões nos geradores são mostrados na Tabela I.




Fig. 1. Sistema IEEE 6 barras.

O motivo da escolha de um sistema relativamente pequeno para a realização das simulações reside na metodologia escolhida em que um número considerado de casos precisou ser analisado, sendo que, em cada caso, o número de variáveis de controle, número de estados do sistema e a exatidão considerada na modelagem do espaço factível levam a um grande número de soluções possíveis e, consequentemente, um grande número de soluções manipuláveis pelo algoritmo de otimização.

TABELA I RESTRIÇÕES DAS VARIÁVEIS DE CONTROLE

	Tap do Transformador T65, T43	Tensão na barra do gerador		Capacitores shunt (MVAR)	
		V1	V2	Q4	Q6
Limite inferior	0,910	1,0	1,1	0,0	0,0
Limite superior	1,110	1,1	1,15	5,0	5,5
Valor discreto	0,91+16*1,25%			10*0,5	10*0,5

De acordo com as condições iniciais dadas em [2], as perdas iniciais do sistema são dadas por 11,61 MW.

Para uma população de 20 partículas, fez-se as simulações para 50 iterações, executadas 50 vezes, nas mesmas condições para os quatro métodos de PSO propostos. Salienta-se que todos as estratégias elaboradas para o PSO neste trabalho convergiram adequadamente. Os resultados são descritos nas tabelas II, III e IV.

TABELA II COMPARAÇÃO DAS PERDAS ATIVAS ÓTIMAS PARA OS QUATRO MÉTODOS

	PSO Clássico	PSO-TVIW	PSO-CF	PSO-TVAC
Média das Perdas Ativas	8,675117	8,674572	8,675668	8,674567
Desvio Padrão das Perdas Ativas	0,000545	0,000017	0,005267	0,000002
Maior valor para Perdas Ativas	8,676923	8,674648	8,701208	8,674580
Menor valor para Perdas Ativas	8,674571	8,674567	8,674567	8,674567

Na tabela II, tem-se o resultado comparativo das perdas ativas ótimas para os quatro métodos propostos. Apesar das variações entre eles serem muito pequenas, o método PSO-

TVAC apresenta melhor valor médio com menor desvio padrão. Seu desempenho dinâmico pode ser melhor observado no gráfico da Figura 2, onde as perdas convergem mais rápido para este método. Outro destaque fica para o PSO-CF que, dentre todos as abordagens, foi a que teve o pior desempenho. Embora tenha convergido para o ótimo desse problema multimodal, essa estratégia além de apresentar a pior média, também apresentou o pior desvio padrão. A explicação pode estar na maneira cautelosa com que essa variação do PSO utiliza na busca do ótimo global. Ao variar um único parâmetro em função do fator de inércia e das constantes de aceleração, esse algoritmo garante a diversidade do algoritmo do início ao fim, sempre evitando a convergência prematura.

TABELA III COMPARAÇÃO DOS RESULTADOS ÓTIMOS PARA OS QUATRO MÉTODOS

	PSO Clássico	PSO-TVIW	PSO-CF	PSO-TVAC
Média das FGbest	8,674567	8,674567	8,675632	8,674567
Desvio Padrão das FGbest	3,12E-07	1,32E-11	0,005273	6,52E-12
Maior valor das FGbest	8,674569	8,674567	8,701207	8,674567
Menor valor das FGbest	8,674567	8,674567	8,674567	8,674567

Na tabela III, tem-se o comparativo entre os resultados da função objetivo para os quatro métodos propostos em 50 simulações para cada um. São apresentados dados relevantes tais como média, desvio padrão, maior e menor valor dentre os métodos. Percebe-se que o PSO-CF convergiu, em média, para um valor diferente dos demais. Além disso, esse método obteve a maior dispersão. O PSO-TVAC obteve a menor dispersão, o que revela a congruência entre as simulações.

Nas tabelas IV e V, tem-se o valor das variáveis de controle para o resultado otimizado dos quatro métodos de PSO propostos para o pior e melhor caso que ocorreram após os 50 experimentos simulados. Nota-se que há uma margem de erro muito baixa ao se comparar o resultado final para todos casos. As pequenas divergências entre os resultados obtidos dentre todos os métodos para todas as variáveis de controle mostram o quanto o PSO é adequado para trabalhar com problemas como os de planejamento do setor elétrico, cujas variáveis de controle são determinantes para garantir confiabilidade e segurança ao sistema.

TABELA IV VARIÁVEIS DE CONTROLE PARA O PIOR CASO

Variáveis de controle	PSO Clássico	PSO-TVIW	PSO-CF	PSO-TVAC
V_1 [pu]	1,100000	1,100000	1,100000	1,100000
V_2 [pu]	1,150000	1,150000	1,150000	1,150000
Q_4 [pu]	5,000000	5,000000	5,000000	5,000000
Q_6 [pu]	5,500000	5,500000	5,500000	5,500000
T_{43} [pu]	0,946087	0,945871	0,941616	0,945872
T_{65} [pu]	0,937713	0,937598	0,910000	0,937601
Perdas [MW]	8,676923	8,674648	8,701208	8,674580

TABELA V

VARIÁVEIS DE CONTROLE PARA O MELHOR CASO

Variáveis de controle	PSO Clássico	PSO-TVIW	PSO-CF	PSO-TVAC
V_1 [pu]	1,100000	1,100000	1,100000	1,100000
V_2 [pu]	1,150000	1,150000	1,150000	1,150000
Q_4 [pu]	5,000000	5,000000	5,000000	5,000000
Q_6 [pu]	5,500000	5,500000	5,500000	5,500000
T_{43} [pu]	0,945871	0,945871	0,945871	0,945871
T_{65} [pu]	0,937600	0,937600	0,937600	0,937600
Perdas [MW]	8,6746	8,6746	8,6746	8,6746




Fig. 2. Variação das perdas ativas ao longo das iterações para sistema IEEE 6 barras.




Fig. 3. Variação da função objetivo ao longo das iterações para sistema IEEE 6 barras.

Os gráficos da Fig. 4 mostram a convergência do fator de penalidade de violação de tensão para os quatro métodos de solução. Observa-se que para o método PSO-TVAC os valores convergiram mais rapidamente nas primeiras iterações, em comparação com os outros métodos.




Fig. 4. Variação do fator de penalidade para violação de tensão ao longo das iterações para sistema IEEE 6 barras.

O gráfico da Fig. 5 mostra o perfil de tensão nas barras de carga, para a melhor solução final otimizada através dos quatro métodos de PSO adotados. Observa-se que o perfil de tensão mantém-se dentro dos limites impostos pelas restrições do problema, não ultrapassando 4% do valor de referência. Estes resultados estão de acordo com as respostas dos gráficos da Figura 4, onde os fatores de penalidade de violações de tensão convergiram para zero ao final das iterações.




Fig. 5. Perfil de tensão para as barras de carga do sistema IEEE 6 barras.

VII. CONCLUSÕES

Neste trabalho foi avaliado o desempenho de quatro métodos de otimização por enxame de partículas no problema de despacho ótimo de reativos, adotando-se como caso base a rede IEEE 6 barras. Os métodos propostos foram do método original (PSO clássico), junto com as três primeiras variações desenvolvidas ao longo do PSO clássico – PSO-TVIW, PSO-CF e PSO-TVAC.

Os resultados mostraram que o método PSO-TVAC apresentou melhor desempenho nos resultados obtidos para a otimização do problema proposto, conforme pode ser observado na Fig. 2, já que a velocidade de convergência é a maior em relação aos demais métodos simulados. Contudo, observa-se que, para esse problema de 6 barras em especial, as perdas do sistema atingiram praticamente o mesmo valor – aproximadamente 8,67 – para todas as variações de TOEP,

incluindo o TOEP clássico. Para os resultados otimizados, obtidos nas simulações envolvendo o PSO clássico, junto com as três primeiras variações, os perfis de tensão nas barras de cargas, conforme mostrados na Fig. 5, estão todos dentro dos limites máximos e mínimos de $\pm 5\%$ dos valores nominais, imposto pelo fator de penalidade de tensão.

Nota-se que as TOEP devem ser constantemente estudadas para se verificar o melhor método para a resolução do problema referente ao DOR nos sistemas de barras do IEEE, para futuramente se verificar a viabilidade da aplicação real dos métodos em qualquer Sistema Elétrico de Potência.

REFERÊNCIAS

- [1] V. A. Sousa, E. C. Baptista, G. R. M. Costa, "A resolução do problema de despacho ótimo de reativos pelo método da função lagrangiana-barreira relaxada". *Pesqui. Oper.*, Rio de Janeiro, v. 28, n. 2, p. 303-320, Aug. 2008. Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-74382008000200008&lng=en&nrm=iso>. access on 08 Dec. 2015. <http://dx.doi.org/10.1590/S0101-74382008000200008>
- [2] A.Q. Badar, B.S. Umre, A.S. Junghare, "Reactive power control using dynamic Particle Swarm Optimization for real power loss minimization", *Electrical Power and Energy Systems*, vol. 41, Issue 1, Oct. 2012, pp 133-136.
- [3] N. K. Sharma, D. S. Babu e Dr. S. C. Choubbe. "Application of Particle Swarm Optimization Technique for Reactive Power Optimization", *IEEE, International Conference on Advances in Engineering, Science /and Management*, vol. 31, 2012.
- [4] Mini V. e S. Kumar, "Diversity Enhanced Particle Swarm Optimization based Optimal Reactive Power Dispatch", *IEEE International Conference on Technological Advancements in Power & Energy*, vol. 1, 2015, pp. 170-175.
- [5] R. Eberhart, J. Kennedy, "A new optimizer using particle swarm theory". In: *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on*, pp. 39-43, 1995.
- [6] E. da C. R. CARVALHO, "Solução de problemas de otimização com restrições usando estratégias de penalização adaptativa e um algoritmo do tipo PSO" *Dissertação de Mestrado. Univ. de Juiz de Fora*, 2014.
- [7] J. Sun, C. Lai and X. Wu, "Particle swarm optimisation: classical and quantum perspectives". Boca Raton, FL: CRC Press, 2012. p. 93.
- [8] R. C. Eberhart e Y. Shi, "Comparing inertia weights and constriction factors in particle swarm optimization," *IEEE Press. Evolutionary Computation*, vol. 1, pp. 84-88, 2000.
- [9] M. Clerc e J. Kennedy, "The particle swarm – explosion, stability, and convergence in a multidimensional complex space", *IEEE Transactions on Evolutionary Computation*, vol. 6, n. 1, Feb. 2002.
- [10] J. Sun, B. Feng, W. Xu. "Particle swarm optimization with particles having quantum behavior", *IEEE Congress on Evolutionary Computation*, Piscataway, NJ, pp. 325-331, 2004.
- [11] K. T. Chaturvedi, M. Pandit, L. Srivastava, "Particle swarm optimization with time varying acceleration coefficients for non-convex economic power dispatch", *Electrical Power and Energy Systems*, vol. 31, 2009, pp.249-257.